

引用格式: WEI Daoquan, WANG Huiqin, WANG Ke, et al. Pigment Classification Method of Mural Sparse Multi-spectral Image Based on Space Spectrum Joint Feature[J]. Acta Photonica Sinica, 2022, 51(4):0430002

蔚道权,王慧琴,王可,等.基于空谱联合特征的壁画稀疏多光谱图像颜料分类方法[J].光子学报,2022,51(4):0430002

基于空谱联合特征的壁画稀疏多光谱图像颜料分类方法

蔚道权¹,王慧琴¹,王可¹,王展²,甄刚²

(1 西安建筑科技大学 信息与控制工程学院, 西安 710055)

(2 陕西省文物保护研究院, 西安 710075)

摘 要:由于受到现场条件和保护要求限制,对壁画进行光谱成像数据采集时需要快速完成,利用稀疏通道成像能够提高数据采集的效率,但其像元颜料光谱反射率曲线呈现非线性,影响壁画多光谱图像颜料分类精度。针对该问题,提出了基于空谱联合特征的壁画稀疏多光谱图像颜料分类方法,采用长短期记忆神经网络中的双曲正切激活函数提取非线性光谱特征,减小对分类精度的影响;针对多光谱成像空间分辨率较高导致相邻像元相关性较强的问题,利用卷积神经网络中线性整流函数把特征图映射到非线性空间,提高模型非线性特征的表达能力;最后使用多尺度融合策略将空间特征和光谱特征相加,消除光谱非线性和空间相关性的问题对分类结果的影响。实验结果表明,OA 和 Kappa 系数分别达到了 97% 和 0.97 以上,有效提高了壁画稀疏多光谱图像的颜料分类精度。

关键词:壁画多光谱图像;颜料分类;空谱联合;卷积神经网络;长短期记忆神经网络

中图分类号:O433.4

文献标识码:A

doi:10.3788/gzxb20225104.0430002

0 引言

壁画是中国文化长河中的瑰宝,在历史、科学和艺术等方面具有很高的研究价值,颜料作为壁画的重要创作材料,是其重要组成部分。由于年代久远及各种环境因素的影响,壁画出现不同程度的画面模糊、颜料脱落等问题,对颜料鉴定和识别是壁画后期维护的重要前提。近年来,多光谱成像技术作为基于成像学和光谱学发展起来的新兴技术,为壁画颜料高效检测识别提供了可靠方法^[1]。多光谱图像是具有数个波段或者数十个波段组成的“数据立方体”,光谱技术与成像技术结合在一幅图像中,含有丰富的光谱信息和空间信息^[2]。在给定已知类别标签的样本数据情况下,多光谱图像颜料的分类实质为通过分析不同颜料的空谱特征来选择特征参数的过程,特征空间被划分成不同的子空间,每个像素点被指定给相关的子空间。

多光谱图像颜料分类逐渐成为光谱数据分析的研究热点,GONG Mengting 等^[3]用高光谱成像系统采集现代中国画的高光谱图像,利用光谱角填图法对绘画所用颜料进行分类和识别;ZHANG Chenfeng 等^[4]对文物颜料光谱吸收特征进行参量化分析,并通过改进的光谱吸收特征拟合算法与标准光谱进行匹配识别,从而得到识别结果;BU Yajing 等^[5]根据不同物质对光的吸收特性不同,提出了一种基于可见光谱的颜料识别方法;LI Junfeng 等^[6]针对取样分析技术破坏壁画文物完整性问题,提出非接触式可见光谱法原位无损识别壁画文物矿物质颜料物质成分和粒径的方法。WANG Yu 等^[7]利用显微激光拉曼光谱仪对大昭寺转经廊壁画颜料进行了分析,并发现壁画中使用了合成有机颜料甲苯胺红。LIANG Jinxing 等^[8]提取光谱曲线的一阶

基金项目:陕西省自然科学基金基础研究计划(No.2021JM-377),陕西省科技厅科技合作项目(No.2020KW-012),陕西省教育厅智库项目(No.18JT006),西安市科技局高校人才服务企业项目(No.GXYD10.1),西安建筑科技大学自然科学专项(No.ZR21033),天津蓟州独乐寺泥塑壁画前期研究项目

第一作者:蔚道权(1996—),男,硕士研究生,主要研究方向为多光谱颜料分类技术。Email: daoquanwei2020@163.com

导师(通讯作者):王慧琴(1970—),女,教授,博士,主要研究方向为智能信息处理、信息理论与应用。Email: hqwang@xauat.edu.cn

收稿日期:2021-09-14; **录用日期:**2021-12-26

<http://www.photon.ac.cn>

与二阶导数特征,构建古代壁画常用颜料库光谱数据库,计算待鉴别颜料与数据库参考样本在光谱特征空间中的匹配误差,实现颜料物质属性的鉴别。LI Junfeng等^[9]提出一种非接触式可见光谱法原位无损识别壁画文物矿物质颜料物质成分和粒径的方法。

特征提取是多光谱图像分类的关键步骤,传统的多光谱图像颜料分类算法只考虑图像的光谱特征,而忽略图像的空间相关性,并且在壁画的采集过程中,稀疏采集导致其光谱反射率非线性较强,其空间分辨率高度相关性,影响壁画多光谱图像分类精度。近年来,深度学习方法被成功用于多光谱图像分类研究^[10-12],与传统多光谱分类算法相比,深度学习方法通过构建网络框架能够自动地从数据中挖掘所需要的深层特征,对分类任务具有较强的鲁棒性,在分类精度方面有较大提升。卷积神经网络(Convolutional Neural Network, CNN)、长短期记忆神经网络(Long Short-Term Memory, LSTM)等深度学习模型被应用于多光谱图像分类,并取得了一定的效果,但是上述模型无法充分利用多光谱图像的空谱信息。

本文提出了一种联合空间信息和光谱信息的多光谱壁画颜料分类方法,采用CNN和LSTM分别提取多光谱图像的空间特征和光谱特征,LSTM中双曲正切激活函数提取多光谱图像非线性特征,CNN中线性整流函数映射特征图到非线性空间,提高稀疏壁画多光谱图像颜料的分类精度。

1 相关原理

1.1 卷积神经网络

壁画多光谱图像稀疏采集会导致图像中光谱反射率的非线性增强,进而影响分类精度。深度学习中卷积神经网络可以提取多光谱数据的非线性特征,其结构内的线性整流函数(Rectified Linear Unit, ReLU)将多光谱数据从线性空间映射到非线性空间。在壁画多光谱图像空间维度中,卷积神经网络将中间特征图经过激活函数再输出,使卷积后的线性映射转换成非线性映射,其结构主要由卷积层、池化层和全连接层组成^[13],其中卷积层第 $l+1$ 层输出表达式为

$$Z^{l+1}(i, j) = \sum_{k=1}^{K_l} \sum_{x=1}^f \sum_{y=1}^f [Z_k^l(s_0 i + x, s_0 j + y) \omega_k^{l+1}(x, y)] + b \quad (1)$$

式中, Z^{l+1} 表示第 $l+1$ 层的特征图输出, Z_k^l 表示第 l 层,第 k 个通道的特征图输出, b 为偏置量, $Z(i, j)$ 为对应输出的特征图像素值, ω_k^{l+1} 为第 $l+1$ 层,第 k 个通道的权重矩阵, K 为特征图的通道数, (x, y) 表示像素点的位置, f 和 s_0 分别对应卷积核的大小和卷积步长。

在多光谱图像分类中,空间信息主要指空间上下文信息,具体表现为相近像元为同类的可能性较大,对于壁画图像来说,待分类颜料属于含其相邻像元数目最多类别的可能性最大,即相邻像元相关性较强,因此引入卷积神经网络提取壁画多光谱中空间维度上的颜料特征。本文所用卷积神经网络架构如图1,其结构由3层卷积层和3层池化层组成,卷积层的卷积核大小为 3×3 ,数量为32,激活函数为ReLU,池化层的步长为 2×2 ,填充方式为SAME。因壁画颜料区域大小形状不一,不同尺度、不同抽象级别的特征对分类结果皆有重要影响,并且随着卷积层数的加深,特征图的大小不断减小,丢失小区域颜料的细节信息。为有效提取不同尺度特征,引入多尺度融合策略将浅层特征与深层特征进行融合,进一步提高壁画多光谱图像分类精度。但是仅利用卷积神经网络提取空间特征太过单一,无法充分利用多光谱图像“图谱合一”的特点,因此

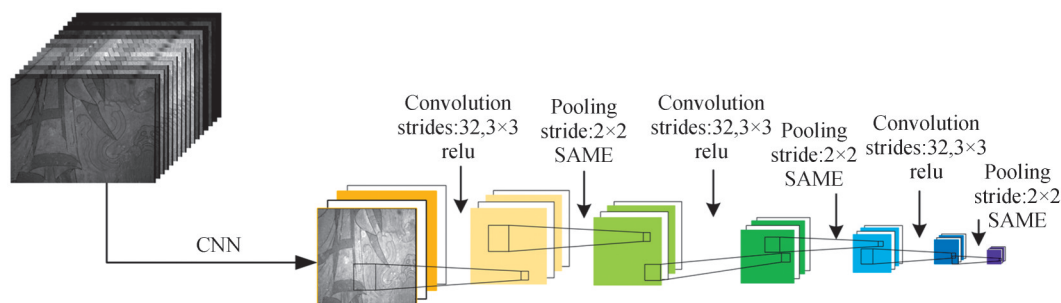


图1 空间特征提取网络结构

Fig. 1 Spatial feature extraction network structure

加入长短期记忆神经网络提取多光谱图像光谱特征。

1.2 长短期记忆神经网络

基于单特征的分类方法精度较低^[14],且稀疏壁画多光谱图像光谱反射率的非线性也会影响分类精度,结合多光谱数据空谱合一的特点,在卷积神经网络的基础上加入长短期记忆神经网络,利用其结构中双曲正切激活函数完成对光谱特征的非线性提取。作为循环神经网络(Recurrent Neural Network,RNN)^[15]的变体,长短期记忆神经网络(LSTM)因能有效抑制RNN反向传播阶段时梯度消失或梯度爆炸^[16]现象,在处理长序列数据时有较好表现。多光谱图像的光谱数据实质上可视为序列数据,其波段之间具有序列相关性。LSTM作为RNN的改进网络,增加了内部状态和门控机制,其主要核心部分包括输入门、遗忘门、输出门和自循环连接。其中输入门 $i^{(t)}$ 控制当前时刻的候选状态信息保存需求量,遗忘门 $f^{(t)}$ 控制上一时刻内部状态遗忘信息需求量,输出门 $o^{(t)}$ 控制当前时刻对外部状态 $h^{(t)}$ 的内部状态输出需求量。步长为 t 的LSTM前向传播过程如式(2)~(6)所示。

InputGate:

$$i^{(t)} = \sigma(W_i x^{(t)} + U_i h^{(t-1)} + b_i) \quad (2)$$

ForgetGate:

$$f^{(t)} = \sigma(W_f x^{(t)} + U_f h^{(t-1)} + b_f) \quad (3)$$

OutputGate:

$$o^{(t)} = \sigma(W_o x^{(t)} + U_o h^{(t-1)} + b_o) \quad (4)$$

CellState:

$$c^{(t)} = i^{(t)} \odot g(W_c x^{(t)} + U_c h^{(t-1)} + b_c) + f^{(t)} \odot c^{(t-1)} \quad (5)$$

LSTMOutput:

$$h^{(t)} = o^{(t)} \odot g(c^{(t)}) \quad (6)$$

式中, $W_i, W_f, W_o, W_c, U_i, U_f, U_o$ 和 U_c 为权重矩阵, b_i, b_f, b_o 和 b_c 为偏差向量, $i^{(t)}, f^{(t)}, o^{(t)}$ 分别表示 t 时刻输入门、遗忘门和输出门的输出, $c^{(t)}$ 和 $c^{(t-1)}$ 表示 t 时刻和 $t-1$ 时刻的状态单元, $h^{(t-1)}, h^{(t)}$ 分别表示 $t-1$ 时刻和 t 时刻网络的输出, σ 为sigmoid激活函数,具体形式为 $\sigma(x) = \frac{1}{1 + e^{-x}}$, \odot 表示点积, g 表示tanh激活函数,形

式为 $g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ 。

如图2所示,将壁画多光谱图像进行光谱重组,输出一维光谱向量到LSTM中,在无监督情况下主动学习深度光谱特征,利用LSTM提取多光谱图像的光谱信息。在光谱维度相邻波段间光谱反射率具有高度相关性,且光谱数据本质为序列数据,LSTM可关注相邻序列数据之间的上下文信息,即相邻波段之间的光谱信息。因此利用上述特性可高效提取多光谱数据中光谱特征,达到多光谱图像高精度分类的目的。

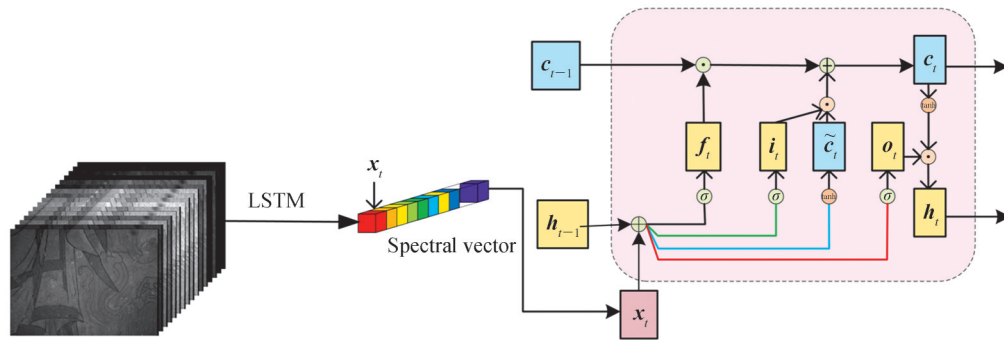


图2 光谱特征提取网络结构

Fig.2 Spectrum feature extraction network structure

1.3 空谱联合特征网络

壁画多光谱图像含有大量空间特征和光谱特征,仅利用CNN提取空间特征或LSTM提取光谱特征无法充分利用壁画多光谱的图像“空谱合一”特性,导致颜料分类精度较低,因此将二者结合为空谱联合特征网络。传统多光谱图像分类方法如 K 近邻法^[17]、最大似然法^[18]及支持向量机^[19]法,仅考虑图像的空间信息或光谱信息,忽略了相应域的光谱信息相关性,且稀疏采集方式对分类精度有一定影响。对于壁画多光谱图像而言,其光谱反射率呈现非线性特点,深度学习中的激活函数可以提取非线性光谱特征。激活函数给神经元加入非线性元素,使神经网络可以逼近任意非线性函数,因此将LSTM和CNN的激活函数引入壁画多光谱图像颜料分类网络中,映射多光谱数据到非线性空间,提高光谱非线性特征的表达能力。

CNN因其强大的特征提取能力,逐渐成为多光谱图像分析的主流算法,但其应用于壁画多光谱图像分类尚存在一些问题。文献[20]将CNN用于高光谱图像分类,由于壁画多光谱图像同时具有丰富的空间信息和光谱信息,且卷积和池化操作只提取壁画二维空间特征,忽略了多光谱图像光谱维度上的光谱特性,很大程度上影响了模型分类性能。壁画多光谱图像的颜料类别复杂多样,仅利用光谱信息或者空间信息很难适应壁画多光谱数据。由文献[21]可知,结合空间和光谱信息的方法可有效提高光谱信息分类精度。文献[22]中提出一种基于3维卷积递归神经网络的高光谱图像分类方法,虽提取了空间信息与光谱信息,但对多通道高分辨率壁画多光谱图像而言,递归神经网络无法处理长序列的多光谱数据。因此利用LSTM时序连接结构提取壁画多光谱图像的光谱特征,解决了多光谱数据非线性对分类结果的影响。

本文将CNN和LSTM整合为空谱联合特征网络(Space-Spectrum Joint Feature, SSJF),网络结构如图3。网络主体由卷积神经网络和长短期记忆神经网络组成,上分支使用LSTM提取光谱特征,通过激活函数Tanh将多光谱输出特征图映射在 $[-1, 1]$ 范围,提取非线性光谱特征的同时有效避免了梯度消失;下分支使用CNN提取空间特征,在卷积后使用ReLU函数映射至非线性空间,调整输出特征矩阵将负值修正为0,大于或等于0的数值保持不变。同时将多通道三维多光谱数据立方体展平为一维光谱向量,输入到LSTM中,通过遗忘门及输出门获取有效光谱特征向量。融合LSTM和CNN所提特征图为空谱联合特征图,经过前向传播建立网络模型,设计网络损失函数,通过反向传播最小化损失函数,最后利用softmax分类器输出每类颜料对应概率值。

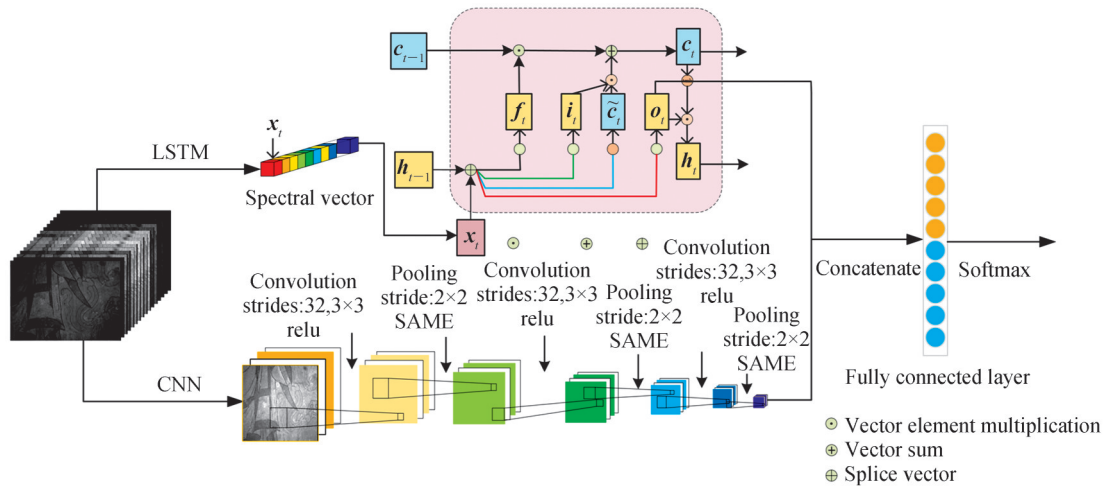


图3 空谱联合特征提取网络

Fig. 3 Space-spectrum joint feature extraction network

整体网络流程为:

Step1:对于上分支LSTM,设 $X \in R^{r \times c \times n}$ 为原始多光谱数据,其中 r, c, n 为多光谱图像高、宽及通道数。将三维多光谱图转换为一维光谱向量,对于当前时刻输入 x_t ,有

$$\begin{bmatrix} \tilde{c}_t \\ o_t \\ i_t \\ f_t \end{bmatrix} = \begin{bmatrix} \tanh \\ \sigma \\ \sigma \\ \sigma \end{bmatrix} \left(\mathbf{W} \begin{bmatrix} x_t \\ h_{t-1} \end{bmatrix} + b \right) \quad (7)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (8)$$

$$h_t = o_t \odot \tanh(c_t) \quad (9)$$

式中, $x_t \in \mathbf{R}^M$ 为当前时刻输入, $\mathbf{W} \in \mathbf{R}^{4D \times (D+M)}$ 和 $b \in \mathbf{R}^{4D}$ 为网络参数, D 为数据维度, M 为超参数; $\tilde{c}_t \in \mathbf{R}^D$ 为通过非线性函数得到的候选状态, c_{t-1} 为上一时刻记忆单元; \tanh 为双曲正切激活函数, 形式为 $\tanh = \frac{e^x - e^{-x}}{e^x + e^{-x}}$, \odot 为向量元素乘积。

Step2: 对于下分支 CNN, 设 $\mathbf{X} \in \mathbf{R}^{r \times c \times n}$ 为原始多光谱数据, 经过三次卷积核最大池化操作后, 第 l 层的输出特征映射为

$$a^l = \text{maxpool}(\text{ReLU}(z^l)) = \text{maxpool}(\text{ReLU}(a^{l-1} \mathbf{W}^l + b^l)) \quad (10)$$

式中, a^l 为第 l 层激活后输出, maxpool 表示最大池化, ReLU 表示线性整流函数, a^{l-1} 为第 $l-1$ 层激活后输出, \mathbf{W}^l 和 b^l 分别表示第 l 层的权重及偏置。

Step3: 将 LSTM 和 CNN 提取的特征进行拼接, 经 Softmax 得到每一类颜料概率值, 对于多光谱图像多分类问题, 类别标签为 $y \in \{1, 2, \dots, C\}$ 。给定一个样本 x , Softmax 回归预测属于类别 c 的条件概率为

$$p(y = c|x) = \text{softmax}(\mathbf{w}_c^T x) = \frac{\exp(\mathbf{w}_c^T x)}{\sum_{c=1}^C \exp(\mathbf{w}_c^T x)} \quad (11)$$

式中, $p(y = c|x)$ 表示样本 x 属于 c 类的概率, \mathbf{w}_c 是第 c 类的权重向量。

网络损失函数定义为

$$\begin{aligned} L_{\text{loss}} = L_{\text{cnn}} + L_{\text{lstm}} + L_{\text{join}} = & -\frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i^{\text{cnn}}) + (1 - y_i) \log(1 - \hat{y}_i^{\text{cnn}})] - \\ & \frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i^{\text{lstm}}) + (1 - y_i) \log(1 - \hat{y}_i^{\text{lstm}})] - \frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i^{\text{join}}) + (1 - y_i) \log(1 - \hat{y}_i^{\text{join}})] \end{aligned} \quad (12)$$

式中, L_{cnn} 、 L_{lstm} 、 L_{join} 分别为卷积神经网络、长短期记忆神经网络和空谱联合特征网络的损失函数, \hat{y}_i^{cnn} 、 \hat{y}_i^{lstm} 、 \hat{y}_i^{join} 为第 i 个训练样本对应的预测标签, y_i 为真实类别标签, m 为训练集的大小。

2 实验及结果分析

2.1 数据集

实验数据集分为两部分, 第一部分为自制多光谱颜料板, 如图 4 所示, 其中包含铬黄、雌黄、藤黄、头绿、四绿、头青、天兰、四青、青金石、深红、大红、朱膘、赭石、银朱 14 种颜料色块多光谱图像, 图像大小为 187×500 , 光谱波段数为 16, 波长分别在 400 nm, 460 nm, 480 nm, 520 nm, 540 nm, 580 nm, 600 nm, 640 nm, 660 nm, 700 nm, 740 nm, 780 nm, 820 nm, 860 nm 和 900 nm。图 4(a) 为在 CIE 标准照明体 D65 光源下 660 nm 处多光谱图像示意图, 图 4(b) 为各种颜料的 RGB 三色图, 多光谱颜料板数据集按 1:9 划分为训练集和测试集, 表 1 为数据集具体划分, 其中 Training 和 Test 两栏分别代表训练集和测试集的像素点个数。第二部分为自制模拟壁画, 如图 5 所示, 图像大小为 1370×1030 , 光谱波段数为 16, 光谱分辨率和多光谱颜料板相同, 其中图 5(a) 为 660 nm 处光谱图像示意图, 图 5(b) 为真彩色图像。

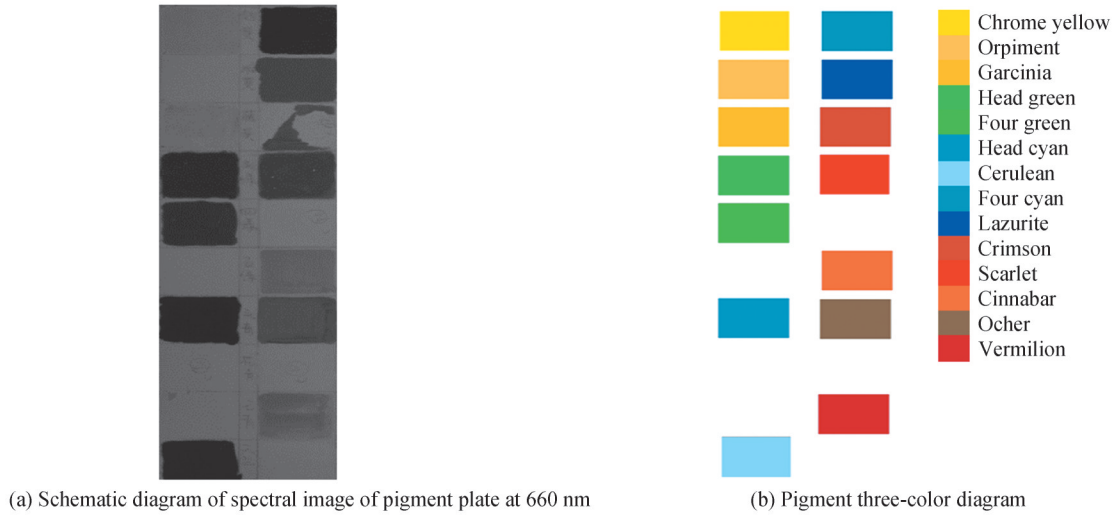


图4 多光谱颜料板

Fig. 4 Multispectral pigment board

表1 多光谱颜料板训练集和测试集划分

Table 1 The division of training set and test set of multispectral paint board

Class number	Class name	Training	Test
1	Chrome yellow	246	2 214
2	Orpiment	248	2 232
3	Garcinia	257	2 313
4	Head green	251	2 259
5	Four green	249	2 160
6	Head cyan	255	2 295
7	Cerulean	261	2 349
8	Four cyan	264	2 376
9	Lazurite	236	2 124
10	Crimson	251	2 259
11	Scarlet	249	2 241
12	Cinnabar	243	2 187
13	Ocher	247	2 223
14	Vermilion	239	2 151
Total		3 496	31 383




图5 自制模拟壁画

Fig. 5 Self-made mock murals

2.2 颜料板及模拟壁画分析

将多光谱颜料板中的颜料标记为训练标签,铬黄标记为1,雌黄标记为2,以此类推,为了定量评价各模型的性能,使用OA和Kappa系数作为性能指标,OA表示训练样本中分类正确的百分比例,越接近100%说明分类精度越高,Kappa系数是基于混淆矩阵的精度衡量指标,代表与完全随机分类相比分类减少的错误百分比,其取值范围为 $[-1,1]$,评价指标可分别表示为

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

$$Kappa = \frac{p_o - p_e}{1 - p_e} \quad (14)$$

式中,TP表示真实值为正样本,预测值为正样本;TN表示真实值为负样本,预测值为负样本;FP表示真实值为负样本,预测值为正样本;FN表示真实值为正样本,预测值为负样本。 p_o 表示每一类正确分类的样本数量之和除以总样本数, $p_e = \frac{(TP + FN) \times (TP + FP) \times (FN + TN) \times (TN + FP)}{N^2}$ 。

采用小批量随机梯度下降算法优化网络模型,训练阶段设置epoch为500,网络采用端到端的方式训练,所有参数通过Adam算法进行优化,初始学习率为0.0001, $\beta_1 = 0.9$, $\beta_2 = 0.999$,batch_size为128,Keras框架搭建空谱联合网络模型,硬件环境为Intel i7-8700,3.20 GHz处理器,16 GB RAM,NVIDIA RTX 2070显卡。

多光谱颜料板训练结果如图6,其中图6(a)为16通道多光谱图,图6(b)为真实类别标签,图6(c)为LSTM分类结果,可以看出其网络大致分类出所标记的颜料的类别,但LSTM更多关注多光谱图像的光谱特征,没有考虑到空间特征,实际分类效果与真实结果相差较远。图6(d)为CNN分类结果,相比于LSTM,可以看出CNN对颜料色块的线条、形状等空间特征分类效果较好。图6(e)为SSJF结果,与只考虑光谱特征或者空间特征的方法相比,空谱联合特征的分类结果更接近类别标签。

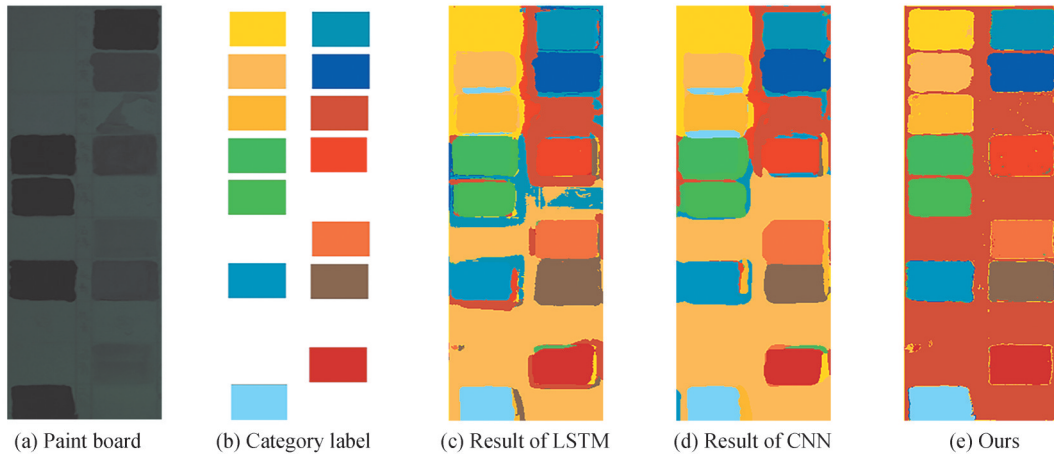


图6 不同方法在颜料板下的训练结果

Fig. 6 The training results of different methods under the paint board

定量分析如表2所示,从表中数据可知空谱联合特征网络对各个颜料的分类的准确度结果较好,相对于只提取光谱特征或只提取空间特征的网络来说,空谱联合特征网络的OA和Kappa系数都高于只提取单一特征的分类方法。

从图7中每个方法对每类颜料的分类结果来看,SSJF对颜料的分类准确度均高于CNN和LSTM的分类准确度,LSTM中tanh和sigmoid激活函数能够给神经网络加入非线性因素,使得LSTM具有良好的非线性逼近能力,CNN中的卷积操作可以提取局部区域的特征信息,避免了相邻颜料错分为相同种类的情况,消除了光谱分辨率非线性和空间相关性对分类结果的影响,并且融合LSTM和CNN提取的光谱信息和空间信息,充分利用多光谱图像的空谱信息,进一步提高了壁画多光谱图像的分类精度。

表2 不同方法在颜料板下的分类精度
Table 2 Classification accuracy of different methods under pigment board

Class	LSTM	CNN	SSJF
Chrome yellow	97.88	99.10	99.77
Orpiment	97.46	98.21	98.17
Garcinia	96.45	98.27	97.97
Head green	96.37	99.34	99.56
Four green	98.52	99.63	99.82
Head cyan	96.27	98.57	99.26
Cerulean	98.64	99.58	98.26
Four cyan	94.82	96.93	97.42
Lazurite	99.85	99.87	99.95
Crimson	94.57	99.25	99.94
Scarlet	93.59	97.24	97.42
Cinnabar	99.22	99.75	99.95
Ocher	98.25	99.37	99.82
Vermilion	99.81	99.58	99.81
OA/%	97.28	98.94	98.99
Kappa \times 100	97.07	98.86	98.91




图7 颜料板分类结果

Fig. 7 Color board classification results

为了验证模型的普适性,将调优后的模型预测自制模拟壁画中的颜料,对模拟壁画分别采用最小距离分类法(Minimum Distance Classification, MDC)、光谱信息散度法(Spectral Information Divergence, SID)、光谱角制图法(Spectral Angle Mapping, SAM)、支持向量机法(Support Vector Machine, SVM)和本文的空谱联合特征网络(Space-Spectrum Joint Feature, SSJF)。实验结果如图8,其中图8(a)为MDC分类结果,从图上来看结果较差,出现颜料错分的情况;图8(b)为SID分类结果,可以看出对细节部分分类较差;图8(c)为SAM分类结果,与SID分类结果相似;图8(d)为SVM分类结果,从图像上可以看出总体精度较好,对于银朱、铬黄、四绿等颜料都得出较为正确的结果;图8(e)和(f)分别为卷积神经网络和长短期记忆神经网络分类结果,图8(g)为空谱联合网络的分类结果,本文算法将CNN和LSTM各自分类残缺的部分进行补齐,对自制壁画中的颜料进行了正确分类,相比于其他传统算法,对自制壁画中人物衣服中的颜料分类的结果更为准确。

为判定分类结果的真实有效,采用主观评价方法和客观评价方法相结合的方式对图像分类结果进行评价,主观图像质量评价方法采用双刺激损伤分级法对壁画多光谱图像的分类结果进行打分。相比主观图像质量评价方法来说,客观评价方法应用更准确、广泛,最常用的有均方根误差(Root Mean Squared, RMSE)

法、峰值信噪比法(Peak Signal to Noise Ratio, PSNR)和结构相似性法(Structural Similarity Image Metric, SSIM)。

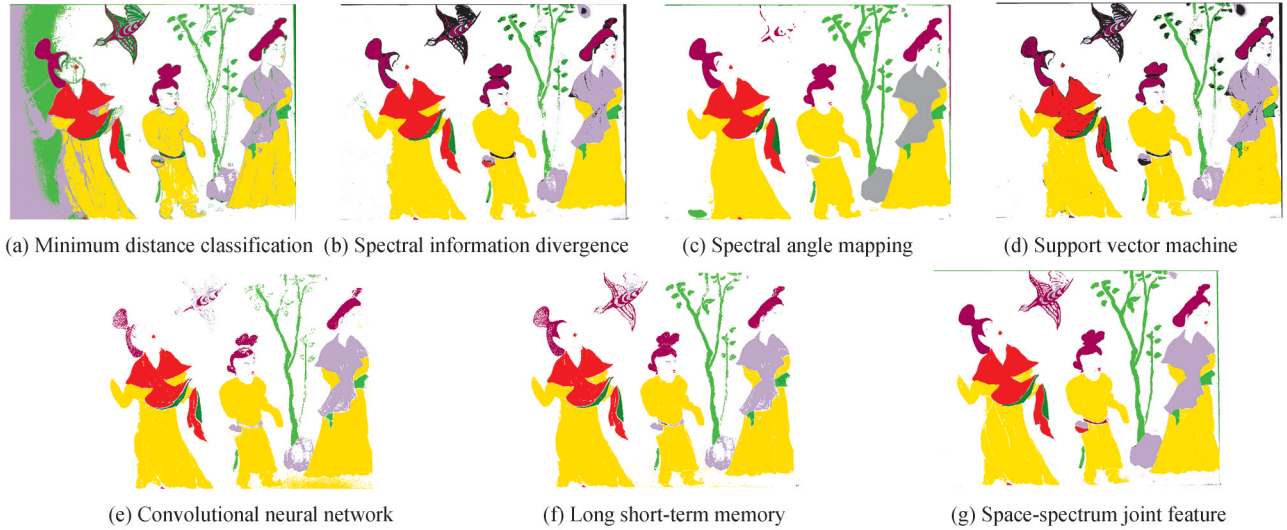


图8 不同方法在自制壁画下的分类结果

Fig. 8 Classification results of different methods under self-made murals

对于主观评价方法,通常采用图像主观质量5级评分表进行打分,邀请陕西省文物保护研究院相关专家和本项目组人员,共10人进行评价,分为5组,每组2人。利用双刺激损伤分级法对比分类结果和原图,观察待测图像的分类结果,根据表3图像主观质量5级评分表,得出待测图像的质量等级,评价结果如表4,MDC为Very bad,SID为Poor,SAM和SVM均为Generally,MSCNN和LSTM均为Better,SSJF为Very good,由表可知,相比较其他算法,SSJF的分类结果较好。

表3 图像主观评价度量尺度表对对比

Table 3 Comparison of the scales of subjective image evaluation

Level	Absolute measurement scale	Relative measurement scale
1	Very good	The best in the group
2	Better	Better than the average in the group
3	Generally	Average in the group
4	Poor	Worse than the average in the group
5	Very bad	Worst in the group

表4 双刺激损伤分级法主观评价结果

Table 4 Evaluation results of dual stimulation injury classification method

Algorithm	Result
MDC	Very bad
SID	Poor
SAM	Generally
SVM	Generally
MSCNN	Better
LSTM	Better
SSJF	Very good

对各算法分类结果采用RMSE、PSNR和SSIM进行客观评价,其中RMSE为预测值与真实值偏差的平方与观测次数比值的平方根,其值越小代表误差越小,越接近真实值;PSNR表示信号最大可能功率和影响它的表示精度的破坏性噪声功率的比值,其数值越高说明与原图越相似;结构相似性SSIM表现在图像的像

素间存在着很强的相关性,其取值范围为 $[0,1]$,值越大,表示图像失真越小,越相似。评价结果如表5,其中SSJF的RMSE、PSNR和SSIM均优于其他分类算法,可知该算法有效地对壁画多光谱图像颜料进行了分类。

表5 图像质量客观评价结果
Table 5 Objective evaluation results of image quality

Algorithm	Evaluation index		
	RMSE	PSNR	SSIM
MDC	39.84	16.12	0.768 8
SID	28.11	19.15	0.887 1
SAM	22.49	19.15	0.894 4
SVM	30.93	18.32	0.864 2
MSCNN	27.81	19.25	0.833 9
LSTM	19.82	22.19	0.880 2
SSJF	2.84	39.06	0.987 4

表6为不同方法对自制模拟壁画的分类精度对比,与LSTM和CNN相比,SSJF对每一类的颜料的分类准确度分别提高了0.11~8.22和0.09~7.12,且OA和Kappa较LSTM提高了1.42和0.024 3,较CNN提高了1.29和0.022 1。综上,空谱联合特征网络明显优于其他传统算法,OA和Kappa系数分别为99.97%和0.999 5。

表6 不同方法对自制模拟壁画的分类精度
Table 6 Classification accuracy of self-made simulated murals by different methods

Class	MDC	SID	SAM	SVM	LSTM	CNN	SSJF
Vermilion	92.23	93.36	95.96	99.38	99.36	99.38	99.47
Chrome yellow	91.37	99.92	99.91	98.97	99.86	99.94	99.97
Four green	93.30	93.24	99.61	98.87	97.63	92.88	100.00
Three green	88.53	98.70	99.85	73.42	91.70	93.89	99.92
Lazurite	82.50	94.64	90.01	98.28	99.23	99.63	99.97
Head green	40.95	66.38	70.34	97.59	95.99	98.18	99.78
OA/%	69.36	97.75	97.54	98.41	98.55	98.68	99.97
Kappa \times 100	46.92	94.45	93.96	97.47	97.52	97.74	99.95

从图9可知,空谱联合特征网络(SSJF)的整体精确度都高于传统壁画多光谱图像分类方法,并且对各个颜料分类精确度基本上都达到了99%以上,Kappa系数(Kappa \times 100)也达到了99.95。相对于其他分类




图9 自制壁画分类结果
Fig. 9 Self-made mural classification results

算法,SSJF 算法都优于单特征算法的分类精度。

2.3 真实壁画多光谱成像数据分析

相比于自制壁画图像,由于受到长期病害的侵蚀,真实壁画表面情况复杂,对颜料分类结果产生较大影响,需要对壁画多光谱图像进行去噪和配准等预处理。真实壁画来自于研究团队在天津某寺庙拍摄的一幅因竭陀尊者图像的部分区域,如图 10 所示,图中左侧为因竭陀尊者真彩图像,右侧为裙子部分的 16 通道光谱图像。搭建 CCD 多光谱相机拍摄环境采集壁画多光谱图像,利用分光元件对目标壁画进行多通道成像,各个通道的像素值代表目标壁画在此通道上的光谱反射情况,将所有通道结合形成数据立方体,再进行图像配准,得到光谱分辨率从 400 nm 到 940 nm 的 16 通道的多光谱图像。




图 10 因竭陀尊者裙子部分 16 通道多光谱图
Fig. 10 16-channel multispectral image of Venerable Injanta's skirt

图 11(a)为原始样本,图 11(b)为分类结果,选取因竭陀尊者裙子部分中 ROI1 和 ROI2 区域作为测试样本,采用调优后的空谱联合特征模型预测样本,得出分类结果,并与标准颜料板进行对比。实验结果表明,空谱联合特征网络分类方法较好地分出了颜料种类,LSTM 中的 Tanh 函数提取的非线性光谱特征,减小了非线性对分类精度的影响,且 LSTM 解决了反向传播阶段产生的梯度消失和梯度爆炸的问题,提高了该壁画中人物裙子的分类效果,同时 CNN 中 ReLU 函数把特征图映射到非线性空间,加速了网络训练的速度,降低了壁画多光谱相邻像元之间的相关性,提高了模型非线性特征的表达能力。CNN 中局部连接及参数共享机制大大减小了训练参数量,使训练更快收敛至全局最小点。同时本文深度空谱联合特征网络也受人眼神经元细胞感受机理的启发,模拟人脑视觉处理信息的机理,建立空谱联合特征深度网络模型。壁画多光谱




图 11 裙子部分区域样本及分类结果
Fig. 11 Partial region samples and classification results of skirts

图像存在同色异谱现象,在不同光源下,不同物质可能显现出相同的颜色,但其光谱反射率不同。本文空谱联合特征网络算法所用数据为光谱数据,其分类结果可从物理层面杜绝颜料分类误差,避免在色度空间的误分类情况。其中ROI1区域和ROI2区域预测准确度分别为99.86%和99.90%,同时模型也预测出其他未知颜料,从图11(b)中分类结果上看,不仅预测出所标记的ROI区域的颜料,且对于ROI1和ROI2以外的区域(图中标记区域)颜料也成功预测,验证了本文空谱联合网络用于壁画颜料分类的有效性。

3 结论

本文提出一种空谱联合特征方法识别壁画多光谱图像颜料类别,利用CNN和LSTM分别提取多光谱图像的空间特征和光谱特征,对壁画颜料进行分类识别。实验结果表明,本文方法可有效地提高待测颜料的分类准确度,并且OA和Kappa系数都高于其他算法。传统基于仪器的测量方法需要直接接触壁画,可能会对文物造成损坏,为避免该问题,采用多光谱成像技术和深度学习算法识别颜料种类,该方法可快速、无损且无接触式地识别出壁画颜料的种类,其分类结果可以作为壁画修复和朝代鉴定的参考材料。

参考文献

- [1] WANG Xuepei, ZHAO Hongxia, LI Qinghui, et al. Relevant basic research on multispectral imaging technology to analyze color artworks[J]. *Acta Optica Sinica*, 2015, 35(10): 312-319.
王雪培, 赵虹霞, 李青会, 等. 多光谱成像技术分析彩色艺术品的相关基础研究[J]. *光学学报*, 2015, 35(10): 312-319.
- [2] LIU Xuefeng, MENG Yue, WANG Hao, et al. Research on hyperspectral image classification method based on three-dimensional residual network and virtual samples[J]. *Modern Electronic Technology*, 2020, 43(12): 145-150.
刘雪峰, 孟月, 王浩, 等. 基于三维残差网络和虚拟样本的高光谱图像分类方法研究[J]. *现代电子技术*, 2020, 43(12): 145-150.
- [3] GONG Mengting, FENG Pingli. A Preliminary study on the application of hyperspectral imaging technology in the classification and recognition of chinese painting pigments—taking spectral angle mapping (SAM) as an example[J]. *Sciences of Cultural Relics Conservation and Archaeology*, 2014, 26(4): 76-83.
巩梦婷, 冯萍莉. 高光谱成像技术在中国画颜料分类和识别上的应用初探——以光谱角填图(SAM)为例[J]. *文物保护与考古科学*, 2014, 26(4): 76-83.
- [4] ZHANG Chenfeng, HU Yungang, HOU Miaole, et al. Research on the pigment recognition of painted cultural relics based on the analysis of spectral absorption characteristics[J]. *Geographic Information World*, 2017, 24(3): 119-123.
张陈峰, 胡云岗, 侯妙乐, 等. 基于光谱吸收特征分析的彩绘文物颜料识别研究[J]. *地理信息世界*, 2017, 24(3): 119-123.
- [5] BU Yajing, WAN Xiaoxia, LI Junfeng, et al. Research on dunhuang mural pigment recognition method based on visible spectrum feature extraction[J]. *Sciences of Conservation and Archaeology*, 2017, 29(3): 45-51.
补雅晶, 万晓霞, 李俊锋, 等. 基于可见光谱特征提取的敦煌壁画颜料识别方法研究[J]. *文物保护与考古科学*, 2017, 29(3): 45-51.
- [6] LI Junfeng, WAN Xiaoxia. Study on nondestructive identification of mineral pigments of mural cultural relics by visible spectroscopy [J]. *Spectroscopy and spectral analysis*, 2018, 38 (1): 200-204.
李俊锋, 万晓霞. 可见光谱法无损识别壁画文物矿物质颜料的研究[J]. *光谱学与光谱分析*, 2018, 38(1): 200-204.
- [7] WANG Yu, ZHANG Xiaotong, WU Na. Raman spectroscopy analysis of pigments in the Mural Paintings in the Passage Gallery of Jokhang Temple in Lhasa[J]. *Acta Light Scattering*, 2017, 29(1): 39-43.
王玉, 张晓彤, 吴娜. 西藏拉萨大昭寺转经廊壁画颜料的拉曼光谱分析[J]. *光散射学报*, 2017, 29(1): 39-43.
- [8] LIANG Jinxing, WAN Xiaoxia. Non-destructive identification method of ancient mural paint based on visible spectrum[J]. *Spectroscopy and Spectral Analysis*, 2017, 37(8): 2519-2526.
梁金星, 万晓霞. 基于可见光谱的古代壁画颜料无损鉴别方法[J]. *光谱学与光谱分析*, 2017, 37(8): 2519-2526.
- [9] LI Junfeng, WAN Xiaoxia. Study on nondestructive identification of mineral pigments of mural cultural relics by visible spectroscopy [J]. *Spectroscopy and spectral analysis*, 2018, 38 (1): 200-204.
李俊锋, 万晓霞. 可见光谱法无损识别壁画文物矿物质颜料的研究[J]. *光谱学与光谱分析*, 2018, 38(1): 200-204.
- [10] LIU Jinxiang, BAN Wei, CHEN Yu, et al. Hyperspectral remote sensing image classification algorithm fused with multi-dimensional CNN[J]. *China Laser*, 2021, 48(16): 159-169.
刘金香, 班伟, 陈宇, 等. 融合多维度CNN的高光谱遥感图像分类算法[J]. *中国激光*, 2021, 48(16): 159-169.
- [11] YANG Shuqin, SONG Zhishuang, YIN Hanping, et al. UAV multispectral remote sensing crop classification method based on deep semantic segmentation[J]. *Transactions of the Chinese Society of Agricultural Machinery*, 2021, 52(3): 185-192.
杨蜀秦, 宋志双, 尹瀚平, 等. 基于深度语义分割的无人机多光谱遥感作物分类方法[J]. *农业机械学报*, 2021, 52

- (3): 185-192.
- [12] MENG Jiajia, WANG Tao. Remote sensing data classification based on deep residual network[J]. Digital Technology and Application, 2019, 37(1): 99-101.
孟佳佳, 王弢. 基于深度残差网络的遥感数据分类[J]. 数字技术与应用, 2019, 37(1): 99-101.
- [13] ZHOU Feiyan, JIN Linpeng, DONG Jun. Summary of convolutional neural network research[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- [14] QU Haicheng, GUO Yue, WANG Yuanyuan. A new space-spectrum combined hyperspectral image classification method [J]. Science of Surveying and Mapping, 2019, 44(8): 82-90.
曲海成, 郭月, 王媛媛. 一种新的空谱联合高光谱图像分类方法[J]. 测绘科学, 2019, 44(8): 82-90.
- [15] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization [J]. arXiv preprint arXiv: 1409.2329, 2014.
- [16] CHEN Jianting, XIANG Yang. A review of research on gradient instability in deep neural network training[J]. Journal of Software, 2018, 29(7): 2071-2091.
陈建廷, 向阳. 深度神经网络训练中梯度不稳定现象研究综述[J]. 软件学报, 2018, 29(7): 2071-2091.
- [17] LI Chan, WANG Junjie, WU Guofeng, et al. Plant classification in agricultural regions based on leaf spectral characteristics[J]. Journal of Shenzhen University (Science and Technology Edition), 2018, 35(3): 307-315.
李婵, 王俊杰, 邬国锋, 等. 基于叶片光谱特征的农业区域植物分类[J]. 深圳大学学报(理工版), 2018, 35(3): 307-315.
- [18] FAN Liheng, LU Junwei, YU Zhentao, et al. Multispectral remote sensing image classification method based on improved maximum likelihood method[J]. Electronic Optics and Control, 2014, 21(10): 52-56+74.
樊利恒, 吕俊伟, 于振涛, 等. 基于改进最大似然方法的多光谱遥感图像分类方法[J]. 电光与控制, 2014, 21(10): 52-56+74.
- [19] LIU Wei, LIU Changhong, ZHENG Lei. Multispectral imaging rice variety identification based on support vector machine [J]. Transactions of the Chinese Society of Agricultural Engineering, 2014, 30(10): 145-151.
刘伟, 刘长虹, 郑磊. 基于支持向量机的多光谱成像稻谷品种鉴别[J]. 农业工程学报, 2014, 30(10): 145-151.
- [20] ZHAO Mandan, REN Zhiqian, WU Gaochang, et al. Hyperspectral image classification using convolutional neural network[J]. Journal of Surveying and Mapping Science and Technology, 2017, 34(5): 501-507.
赵漫丹, 任治全, 吴高昌, 等. 利用卷积神经网络的高光谱图像分类[J]. 测绘科学技术学报, 2017, 34(5): 501-507.
- [21] LI Tie, SUN Jinguang, ZHANG Xinjun, et al. Research on the joint classification method of hyperspectral remote sensing image space spectrum[J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1379-1389.
李铁, 孙劲光, 张新君, 等. 高光谱遥感图像空谱联合分类方法研究[J]. 仪器仪表学报, 2016, 37(6): 1379-1389.
- [22] GUAN Shihao, YANG Yuan, LI Hao, et al. Classification method of hyperspectral image based on 3D convolutional recurrent neural network[J]. Laser Technology, 2020, 44(4): 485-491.
关世豪, 杨桃, 李豪, 等. 3维卷积递归神经网络的高光谱图像分类方法[J]. 激光技术, 2020, 44(4): 485-491.

Pigment Classification Method of Mural Sparse Multi-spectral Image Based on Space Spectrum Joint Feature

WEI Daoquan¹, WANG Huiqin¹, WANG Ke¹, WANG Zhan², ZHEN Gang²

(1 School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

(2 Shaanxi Provincial Institute of Cultural Relics Protection, Xi'an 710075, China)

Abstract: Murals are treasures in the long history of Chinese culture. It has high research value in history, science and art. Pigment is the material carrier of the main form of mural expression. Simultaneously, it is also an important part of murals. After a long period of disease and corrosion, the surface of the mural may be damaged to varying degrees, making it difficult for researchers to distinguish the type of pigments in the murals. The accurate identification of pigments is the premise of conservation and restoration of cultural relics. The traditional method needs to take samples from the murals, which will cause irreversible damage to the murals. In this paper, multispectral imaging technology and deep learning related classification algorithm are used to analyze and identify the pigments in mural multi-spectral images to assist researchers

in mural identification and cultural relic restoration. Rich spatial and spectral information is included in mural multispectral images. In traditional algorithms, spatial or spectral information is used as a feature of mural multispectral image classification. This method leads to low classification accuracy of mural multi-spectral image. In order to improve the classification accuracy of mural multispectral images, the deep learning algorithm is used in this paper, which can make full use of the spatial and spectral information of multi-spectral images. In the actual shooting, due to the limitations of site conditions and protection requirements, mural spectral imaging data need to be collected quickly. The efficiency of data acquisition can be improved by using sparse channel imaging methods. However, this method can make the spectral reflectance curve of pigments appear nonlinear, which can affect the classification accuracy of mural multi-spectral image. In order to solve this problem, a pigment classification method for mural sparse multi-spectral images based on spatial spectral combination features is proposed in this paper. The nonlinear spectral features are extracted by using the hyperbolic tangent activation function in the Long Short-term Memory (LSTM). Firstly, the spectral reconstruction of the mural multi-spectral image is carried out. Then the one-dimensional spectral vector is input into LSTM, which can actively learn under unsupervised conditions to reduce the influence of spectral curve nonlinearity on the classification accuracy. In order to solve the problems of high spatial resolution and strong correlation between adjacent pixels in multispectral imaging, the linear correction function in Convolution Neural Network (CNN) is used to map the feature map to nonlinear space. The activation function is added after the convolution operation of each layer to improve the nonlinear expression ability of the mural multi-spectral image. The spatial spectral unity of mural multi-spectral images can not be fully utilized, if only spatial or spectral features are used. For this reason, the multi-scale fusion strategy combining spectral and spatial features is used to eliminate the influence of spectral nonlinearity and spatial correlation on the classification results. Firstly, a Spatial Spectral Joint Feature Network Model (SSJF) is established to train pigment samples. Then, the loss function is designed by cross entropy, and the gradient is updated by back propagation algorithm. Finally, the softmax classifier is used to output the probability of each pigment. The experimental results show that the pigments in the paint board and self-made murals can be correctly classified through SSJF. The OA and Kappa coefficients reached 97% and 0.97, respectively, which effectively improved the pigment classification accuracy of the sparse multi-spectral image of the mural.

Key words: Mural multispectral image; Pigment classification; Spectral - Spatial unified; Convolutional neural network; Long short-term memory neural network

OCIS Codes: 300.6550; 240.6645; 110.2350

Foundation item: Natural Science Basic Research Plan in Shannxi Province (No. 2021JM-377), Science and Technology Cooperation Projects in Department of Science and Technology of Shaanxi Province (No. 2020KW-012), Think Tank Project in Department of Education of Shaanxi Province (No. 18JT006), Talent Service Enterprise Project of Science and Technology University in Xi'an City (No. GXYD10.1), Natural Science Project of Xi'an University of Architecture and Technology (No. ZR21033), Early Research Project of Clay Sculpture Murals in Dule Temple, Jizhou, Tianjin